

MODEL ZA PROCJENU VOLUMENA KRUPNOG DRVETA STABALA SMREKE (*PICEA ABIES KARST*) NA PODRUČJU KANTONA 10 U FEDERACIJI BOSNE I HERCEGOVINE

MODEL FOR ESTIMATION MERCHANTABLE WOOD VOLUME OF SPRUCE (*PICEA ABIES KARST*) IN CANTON 10, FEDERATION OF BOSNIA AND HERZEGOVINA

Besim BALIĆ¹, Ante SELETKOVIĆ², Ahmet LOJO¹, Aida IBRAHIMSPAHIĆ¹, Jusuf MUSIĆ¹, Admir AVDAGIĆ¹, Velić HALILOVIĆ¹

SAŽETAK

U radu su korišteni podaci izmjere 377 modelnih stabala smreke koja su mjerena u oborenom stanju na širem području unutar državnih raznodbnih sastojina u Kantonu 10 (Hercegbosanski Kanton). Za određivanje volumena krupnog drveta stabala primijenjena je metoda sekcioniranja sa sekcijama nejednakih apsolutnih dužina (najčešće od 1 – 2 m). Za izravnjanje veličina volumena krupnog drveta od prsnog promjera i visine stabala primijenjena je metoda višestruke regresijske analize. Za procjenu parametara korištenih funkcija, testiranje značajnosti njihovih razlika te provođenje raznih transformacija, kao softversko rješenje korišteni su *StatGraphics Centurion XVII.* i *Statistica 8.0*. U cilju izbora „najboljeg“ modela za procjenu volumena krupnog drveta testiran je veći broj poznatih dendrometrijskih dvoparametarskih volumenskih funkcija. Kvaliteta izjednačenja i prikladnost testiranih modela ocjenjivani su na bazi utvrđenih veličina osnovnih statističkih pokazatelja za karakteriziranje jačine korelačijskih veza. Najbolje ocjene parametara pokazao je model $V_7=a_0+a_1d_{1,3}+a_2h+a_3d_{1,3}h+a_4d_{1,3}^2+a_5d_{1,3}^3h$ uz utvrđeni koeficijent determinacije: $R^2 = 0,99$ i veličinu standardne greške regresije $S_{ey}=0,24\text{ m}^3$. Testirajući značajnost razlika između stvarnih volumena stabala iz uzorka i volumena tih istih stabala utvrđenih primjenom odabranog regresijskog modela, utvrđen je prosječni postotak odstupanja od 0,44%. To znači da su u prosjeku za 0,44% niži volumeni u odnosu na stvarne volumene na uzorku od 377 stabala smreke, što ukazuje da je ovaj regresijski model upotrebljiv za primjenu u praktičnom radu, jer je taj prosječni postotak manji od 1%.

KEY WORDS: smreka, volumen krupnog drveta, regresijski model, nelinearna regresija, dvoulazne volumenske tablice.

UVOD

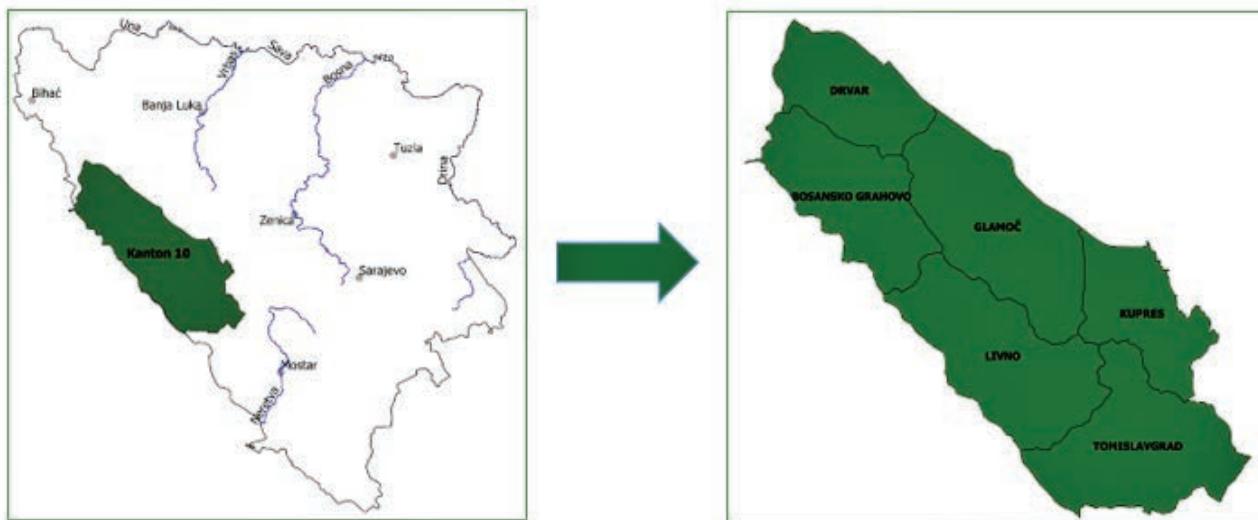
INTRODUCTION

Za procjenu zalihe u okviru uobičajenih poslova prilikom izrade šumskogospodarskih osnova (ŠGO), zatim u realizaciji godišnjih planova sječa i praćenju realizacije istih te formiranja ukupnog prihoda u šumarstvu, kao znanstveno

uporište koriste se volumenske tablice i tarife. Međutim, postoje indicije da se primjenom volumenskih tablica i tarifa koje se trenutno koriste u uređajnoj praksi u BiH (Drinić i dr. 1990) dobivaju određene razlike u količini drvene mase krupnog drveta u odnosu na stvarno stanje tih volumena. Kao uporište u objašnjenju navedenih razlika стоји saznanje da su one konstruirane na bazi volumenskih koeficijenata

¹ Izv. prof. dr. sc. Besim Balić, e-mail: b.balic@sfsa.unsa.ba; Izv. prof. dr. sc. Ahmet Lojo, Izv. prof. dr. sc. Aida Ibrahimspahić, Izv. prof. dr. sc. Jusuf Musić, doc. dr. sc. Admir Avdagić, Izv. prof. dr. sc. Velić Halilović: Šumarski fakultet Univerziteta u Sarajevu, Zagrebačka 20, BiH - 71000 Sarajevo.

² Izv. prof. dr. sc. Ante Seletković, Sveučilište u Zagrebu, Šumarski fakultet, Zavod za izmjeru i uredovanje šuma, Svetosimunska 25, HR-10002 Zagreb, Hrvatska



Područje istraživanja – Kanton 10 Federacije BiH
Research area – Canton 10 Federation of BiH

stabala preuzetih iz njemačkih voluminskih tablica stabala koja potiču iz jednodobnih sastojina, što upućuje na opravdanu sumnju da one daju nešto veći volumen stabala od stvarnog, jer su pri jednakim veličinama prsnog promjera i visina stabala veći volumni koeficijenti stabala koja su uzgojena u jednodobnim u odnosu na stabla koja potiču iz raznодobnih i prebornih sastojina. Drugim riječima, stabla iste vrste drveća koja potiču iz jednodobnih sastojina su punodrvnija u odnosu na stabla iste vrste iz raznодobnih i prebornih sastojina (Koprivica i Maunaga, 2008). To se, naravno, nepovoljno odražava na procjenu bilance ostvarene i planirane proizvodnje drvnih sortimenata, a samim tim i na planirane i ostvarene prihode koji su realiziraju tijekom uređajnog perioda nekog šumskogospodarskog područja, što kontinuirano stvara razne probleme u tekućem poslovanju.

Poznato je da većina naših voluminskih tablica sadrži utabličene veličine različitih grafičkih, pa i analitičkih izjednačenja za koja nisu poznati parametri matematičkih modela funkcija izjednačenja, kao ni mjeru pouzadnosti procjene volumena. Utabličene vrijednosti volumena kao takve nisu prikladne za automatiziranu kompjutersku obradu podataka. Iz tih razloga se nameće kao potreba iznalaženje matematičkih modela za procjenu volumena stabala kojim bi se na jedan brz, jednostavan i, ponajprije, učinkovit način uz dozvoljena odstupanja moglo pouzdano izračunati veličine volumena krupnog drveta, kako pojedinačnih stabala, tako i većih kompleksa šuma (sastojina, gazdinska klasa (GK), ŠGP,...).

Zato je u fokusu ovih istraživanja iznalaženje „najboljih“ regresijskih modela za izjednačenje volumena krupnog drveta stabala smreke, kao zavisne varijable, od promjera i visine stabala, kao nezavisnih varijabli.

MATERIJAL I METODE MATERIAL I METHODS

Polazni materijal kao baza za izradu ovog rada predstavljali su podaci izmjere 377 modelnih stabala izabranih na širem području unutar državnih raznодobnih sastojina u Kantonu 10 (Hercegbosanski Kanton). Odabrana stabla su mjerena u oborenom stanju metodom sekcioniranja sa sekcijama nejednakih apsolutnih dužina (najčešće od 1 – 2 m).

Prilikom izbora modelnih stabala vodilo se računa da u uzorku budu zastupljena stabla svih debljinskih i visinskih stupnjeva. Osim toga težilo se da u uzorak budu zastupljena stabla smreke iz raznih područja shodno njihovom proporcionalnom učešću u zalihi smrekovih stabala cijelog područja (Tablica 1).

Također je prikazana i distribucija broja modelnih stabala po debljinskim i visinskim stupnjevima (Tablica 2).

Iz tablice 2 je razvidno da su izabrana stabla smreke u rasponu od 10,0 cm pa do 110,0 cm prsnog promjera, te od 5 do 45 metara visine. Stabla su skoro ujednačeno distribuirana po debljinskim stupnjevima do debljinskog stupnja 67,5 cm, nakon čega njihov broj opada, jer je i udio takvih

Tablica 1: Distribucije broja modelnih stabala smreke po općinama
Table 1: Distributions of the number of model trees of spruce by municipality

Naziv općine Name of the municipality	Broj modelnih stabala Number of model trees
Kupres	15
Livno	4
Glamoč	144
Grahovo	126
Drvar	86
Tomislavgrad	2
<i>Ukupno - Total</i>	<i>377</i>

Tablica 2. Distribucija ukupnog broja modelnih stabala smreke prema debljinskim i visinskim stupnjevima

Table 2. Distribution of the total number of model trees of spruce according to diameter and height degrees

Promjer (cm) Diameter (cm)	Visina (m) – Height (m)								n _i Broj – No	%
	7,5	12,5	17,5	22,5	27,5	32,5	37,5	42,5		
12,5	6	17							23	6,10
17,5		18	6	2					26	6,90
22,5		4	23	5					32	8,49
27,5		1	8	22					31	8,22
32,5			3	14	15				32	8,49
37,5			1	19	12				32	8,49
42,5			1	4	20				25	6,63
47,5				5	16	1			22	5,84
52,5				1	17	12			30	7,96
57,5					13	15			28	7,43
62,5			2	5	19				26	6,90
67,5				9	14	2			25	6,63
72,5				1	2	10			13	3,45
77,5				1	4	8			13	3,45
82,5					1	3	2		6	1,59
87,5					1	7	1		9	2,39
92,5							1		1	0,27
97,5						1	1		2	0,53
102,5									0	0,00
107,5						1			1	0,27
SUMA - Sum	6	40	42	74	109	71	31	4	377	
%	1,59	10,61	11,14	19,63	28,91	18,83	8,22	1,06	100,00	

stabala u osnovnom skupu znatno manji. Distribucija broja stabala po visinskim stupnjevima je nešto drukčija, po obliku je slična normalnoj distribuciji, pri čemu je najviše stabala zastupljeno u rasponu od 20-35 m visine, a najmanje u najnižem i najvišem visinskom stupnju.

Za određivanje volumena krupnog drveta stabala primjenjena je složena Huberova formula (Banković i Pantić, 2006; Pranjić i Lukić, 1997). Za izjednačenje veličina volumena krupnog drveta od prsnog promjera i visine stabala primijenjena je metoda višestruke regresijske analize. Za kreiranje regresijskog modela, ponajprije za utvrđivanje pa-

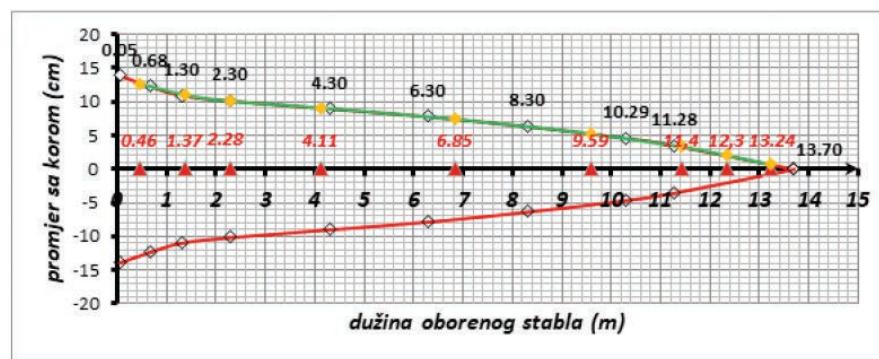
rametara modela korišten je programski paket *Statistica 8.0* u okviru kojega je izabrana metoda nelinearne regresije (*Nonlinear Estimation*) na nivou značajnosti od 95%.

REZULTATI I DISKUSIJA

RESULTS AND DISCUSSION

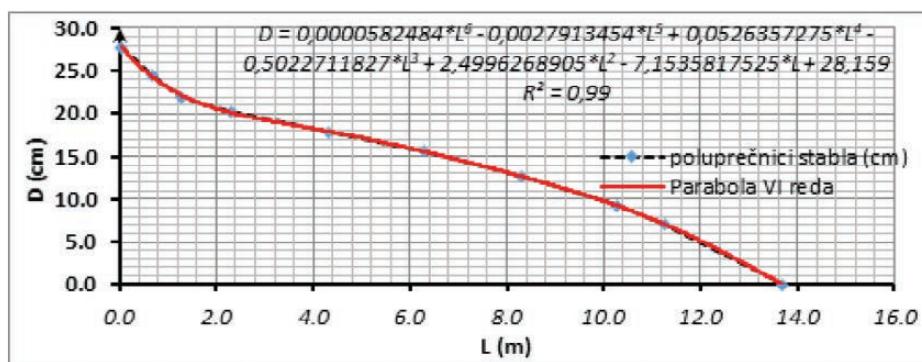
Preliminarna obrada podataka – *Preliminary data processing*

Prije početka obrade i korištenja podataka mjerenja provedena je logička kontrola unesenih podataka izmjere te iz-



Slika 1. Grafički prikaz uzdužnog presjeka stabla za stablo smreke br.23. ŠGP "Livanjsko", GJ „Troglav“, odjel 23., odsjek a sa ucrtanim pozicijama promjera na sredinama sekcija (crveni trokuti) i funkcijom izjednačenja (zeleni liniji)

Figure 1. Example of a graphical representation of a longitudinal section of a tree (spruce tree No.23. ŠGP "Livanjsko", GJ "Troglav", Compartment 23, Subcompartment a with marked positions of diameters at the middle of the sections (red triangles) and a smoothing function (green line)



Slika 2. Primjer grafičkog prikaza izravnjana ovisnosti polumjera stabla od njihove udaljenosti od debljeg kraja stabla parabolom VI reda.

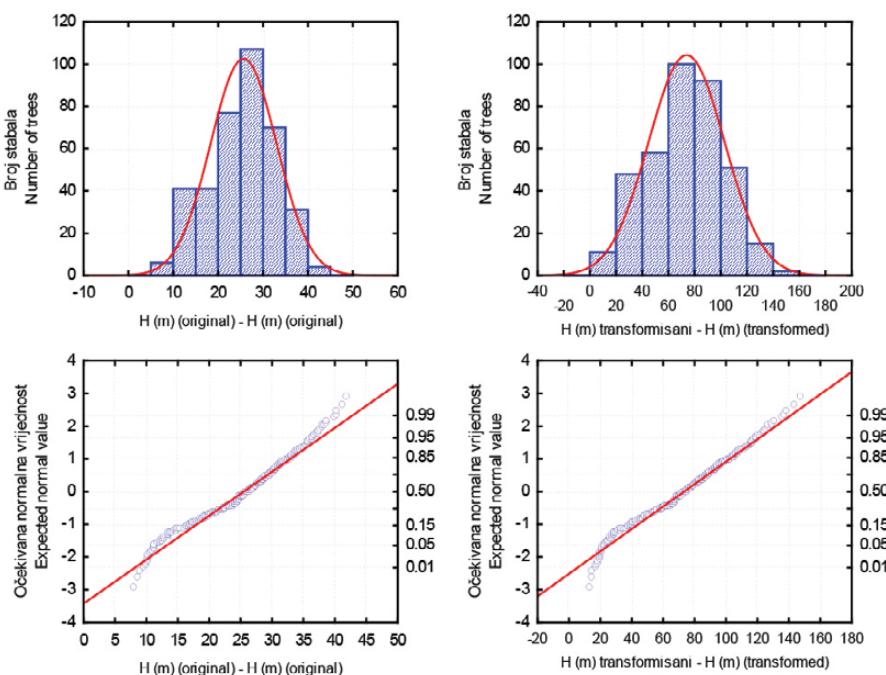
Figure 2. An example of a graphical representation of the equalization of the dependence of the diameter of the tree on their distance from the thicker end of the tree by a parabola of VI order

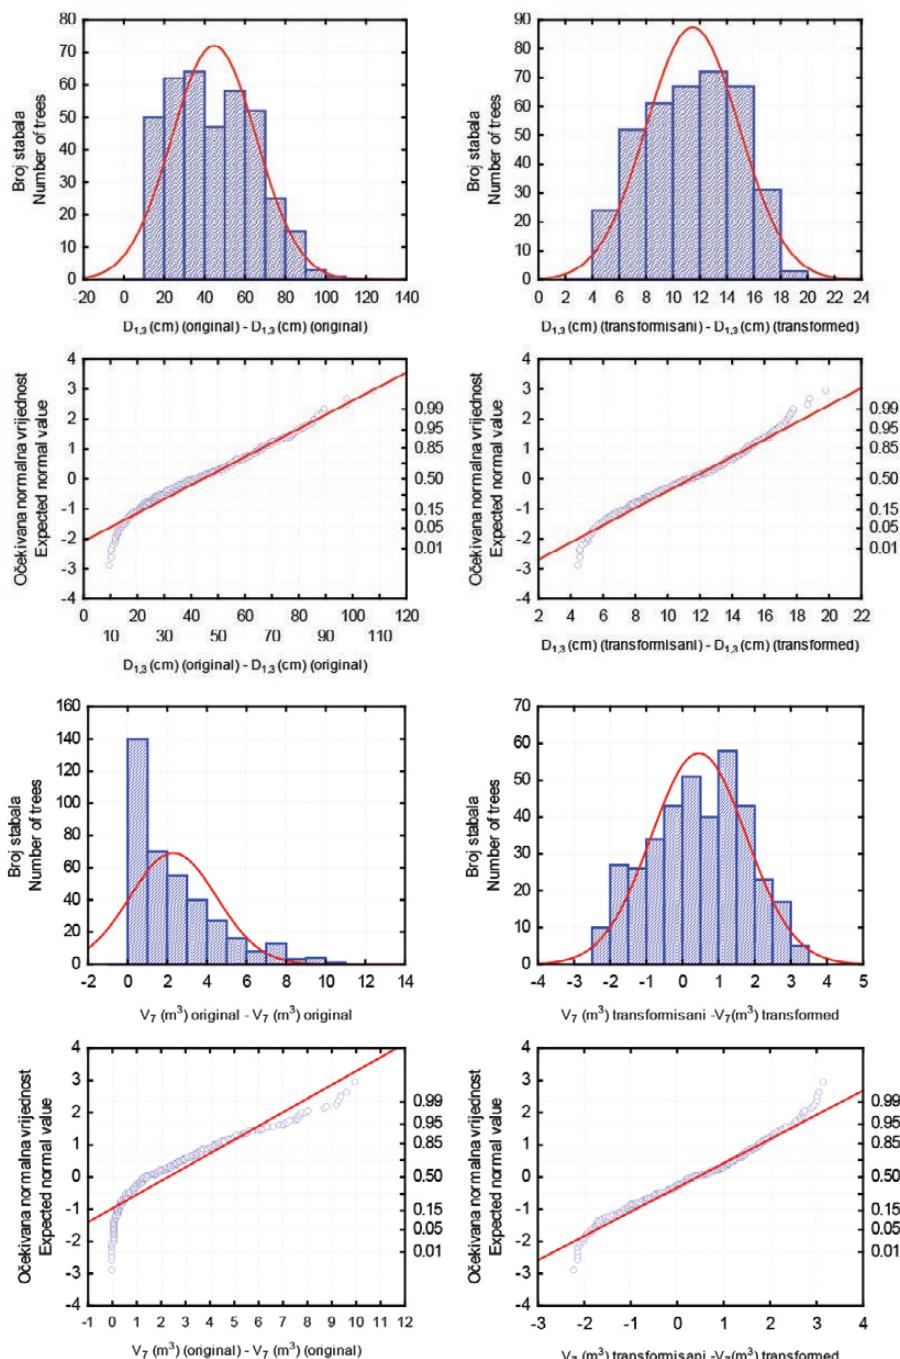
vršene potrebne korekcije. U cilju provođenja logičke kontrole, a posebice za obračun veličina promjera u sredinama sekcija jednakih relativnih dužina po metodama Hohenadla i Altera za svako modelno stablo kreiran je jedan matematičko-statistički model uzdužnog presjeka stabla, čije konturne linije (tzv. morfološke krive stabla, Banković i Pantić, 2006) zapravo predstavljaju ovisnost promjera stabla od udaljenosti datog presjeka (promjera) od debljeg kraja stabla, odnosno od visine panja. Izgled takvog jednog modela predstavljen je na slici 1.

Kao što se vidi iz uzdužnog presjeka stabla konturne linije stabla predstavljene crvenom bojom dobivene su spajanjem promjera izmjerениh u sredinama sekcija iznad kojih su upisane vrijednosti za udaljenost tih promjera od podnožja stabla (kvadratići sa numeričkim podacima crne boje). Da bi se dobole veličine promjera na sredinama sekcija po Alteru i Hohenadlu korištena je krivolinijska korelacijska ovi-

snost promjera stabla od izmjerenih promjera iskazana parabolama višeg reda (IV, V i VI reda). Na bazi izračunatih parametara modela moguće je izračunati promjer na bilo kojoj udaljenosti od debljeg kraja stabla (Koprivica i Mau-naga, 2008). Ta ovisnost je na istom prikazu predstavljena zelenom linijom, a što je na slici prikazano ucrtanim pozicijama promjera na sredinama sekcija (crveni trokuti) i funkcijom izjednačenja (zelena linija).

Na slici 2, primjenom parabole VI reda dan je (kao primjer) grafički prikaz izjednačenja ovisnosti polumjera stabla od njihove udaljenosti od debljeg kraja stabla, sa pripadajućim statističkim pokazateljima (funkcijom modela izjednačenja sa izračunatim parametrima i koeficijentom korelacije kao pokazateljem jačine korelacijske veze). Utvrđeni oblik izravnjanja predstavljen je na slici krivuljom crvene boje. Može se zaključiti visok stupanj suglasnosti empirijskog i procijenjenog oblika modela izravnjanja.





Slika 3. - Oblici distribucija i grafikoni normalne vjerovatnoće varijabli uključenih u regresiju prije i nakon provedene Box-Cox transformacije za smreku
Figure 3 - The forms of distribution and normal probability plots of variables included in the regression before and after an Box-Cox transformation for spruce

Na taj način je za svako stablo proveden isti postupak i obavljena provjera izmjerenih veličina za promjere i dužine. Na osnovi navedenog modela, izračunati su promjeri u sredinama sekcija jednakih relativnih dužina po Alteru (Banković i Pantić 2006) i to: $d_{0,033h}$, $d_{0,1h}$, $d_{0,167h}$, $d_{0,3h}$, $d_{0,5h}$, $d_{0,7h}$, $d_{0,833h}$, $d_{0,9h}$ i $d_{0,967h}$, a na osnovi njih i volumeni stabala sa korom po Hohenadlu ($V = 0,2L \frac{\pi}{4} (d_{0,1}^2 + d_{0,3}^2 + d_{0,5}^2 + d_{0,7}^2 + d_{0,9}^2)$), Hohenadlov pravi oblični broj $f_{0,1} = 0,2 (1 + K_{0,3}^2 + K_{0,5}^2 + K_{0,7}^2 + K_{0,9}^2)$ te pripadajući pravi i nepravi koeficijenti oblika stabla (Kramer i Akça, 2007). Vrijednosti nepravog ili prsnog obličnog

broja (-volumnog koeficijenta) su izračunate po sljedećoj formuli: $f_{1,3} = \nu/w$ gdje su: $f_{1,3}$ – volumni koeficijent; ν – volumena stabla; w – volumen cilindra izračunat po formuli $w = g_{1,30} \cdot h$. Prije bilo kakvih izjednačenja, bilo je potrebno provesti test normalnosti varijabli uključenih u regresijski model. To zapravo znači, da je na empirijske (stvarne) podatke izmjere za promjere i visine stabala, kao nezavisne varijable i izračunate volumene krupnog drveta, kao zavisne varijable bilo potrebno provesti test normalnosti i homogenosti varijanci. U proceduri preispitivanja oblika distribucija zavisne i ne-

Tablica 3. Rezultati Box-Cox transformacije za varijable prsnog promjera, visine i volumen krupnog drveta stabala smreke**Table 3.** Results of the Box-Cox transformation of the variable diameter at breast height, height and merchantable wood volume of spruce trees

Varijabla -variable	Lambda (λ)	Sredina Mean	St.andardna devijacija Standard deviation	Donja granica intervala pouzda- nosti Lower Confidence Limit	Gornja granica intervala pouzdanosti Upper Confidence Limit	Formula za Box-Cox transformaciju The formula for the Box-Cox transformation
D _{1,3} (cm)	0,517374	11,40557	3,44414	0,322304	0,715450	((D _{1,3} ^(0,517374)) - 1) / (0,517374)
H (m)	1,431997	73,30219	28,86548	1,131460	1,740214	((H ^(1,431997)) - 1) / (1,431997)
V _v (m ³)	0,261290	0,43416	1,31101	0,182494	0,341722	((V _v ^(0,261290)) - 1) / (0,261290)

zavisnih varijabli koje su korištene za kreiranje modela regresije, uočeno je da ti oblici značajnije odstupaju od oblika normalne raspodjele kao teoretskog modela, te s toga, u cilju postizanja konvergencije obliku normalne raspodjele, zahtijevaju postupak transformacije. Izborom procedure Box-Cox transformacije (Box i Cox 1964) na originalne vrijednosti varijabli uzetih u regresiju, dobiveni su transformirani oblici distribucija, pri čemu se može zaključiti da su rezultirajuće (transformirane) vrijednosti varijabli približno normalno distribuirane (Slika 3).

Rezultati provedene Box-Cox transformacije za sve tri varijable predstavljeni su u tablici 3.

Tek nakon izvršene transformacije varijabli provedeno je testiranje prikladnosti većeg broja regresijskih modela za direktno izravnanje volumena stabala u ovisnosti od prsnog promjera i visine stabala.

Ovisnost volumena krupnog drveta o prsnom promjeru i visini stabala smreke – Dependence of the volume of big timber of breast height diameter and height of trees spruce

Ako se krene od opće formule za volumen dubećeg stabla $v = g \cdot h \cdot f$ može se zaključiti da se mogu izraditi tablice koje sadrže podatke o volumenima izračunatim po navedenoj formuli. Ovakve tablice nose naziv volumne tablice (tablice drvnih masa, drvnogromadne tablice). Iz dane formule također se vidi da je volumen funkcija tri veličine: prsnog promjera, odnosno temeljnice, ukupne visine i običnjeg broja (volumnog koeficijenta) stabla. Ova višestruka ovisnost volumena je osnova za klasifikaciju volumnih tablica, pri čemu se u tu svrhu koristi broj argumenta („ulaza“). Za argumente se uzimaju veličine o kojima volumen najviše ovisi, a koje se mogu lako mjeriti ili dovoljno

Tablica 5: Oblici izraza i osnovni statistički parametri testiranih dvoparametarskih modela za izjednačenje volumena krupnog drveta stabala smreke u ovisnosti o prsnom promjeru i visini stabla**Table 5:** Forms of expression and basic statistical parameters of the tested two-parameter models for leveling merchantable wood volume of spruce trees depending on the breast diameter - d_{1,3} (cm) and tree height - h (m)

Naziv modela – Model name	Matematički oblik modela – Mathematical form of the model	R ²	R	S _{ey}
1.NÄSLUND:	$V_v = b_1 d_{1,3}^2 + b_2 d_{1,3} h + b_3 d_{1,3} h^2 + b_4 h^2$	0,989	0,994	0,247
2.MEYER:	$V_v = a_0 + a_1 d_{1,3} + a_2 d_{1,3} h + a_3 d_{1,3}^2 + a_4 d_{1,3} h^2$	0,990	0,995	0,245
3.SCHUMACHER-HALL:	$V_v = a d_{1,3}^{b h^c}$	0,990	0,995	0,244
4.SPURR:	$V_v = a (d_{1,3}^2 h)^b$	0,990	0,995	0,640
5.TAKATA:	$V_v = (d_{1,3}^2 h) / (b_0 + b_1 d_{1,3})$	0,637	0,798	0,589
6.DWIGHT:	$V_v = a d_{1,3}^{b h^{(3-c)}}$	0,990	0,995	0,244
7.SPURR:	$V_v = b_0 + b_1 d_{1,3}^2 h$	0,648	0,805	0,243
8.SCOTT:	$V_v = a + b d_{1,3}^c + d d_{1,3}^e h^f$	0,948	0,974	0,629
9.NAGEL:	$V_v = e^{(a * \ln(d_{1,3}) + b * \ln(h - 1,3) - c)}$	0,990	0,995	0,245
10. STOJANOVIĆ I DR.	$V_v = b_0 d_{1,3}^2 + b_1 d_{1,3} h + b_2 d_{1,3} h^2 + b_3 h^2$	0,989	0,994	0,247
11.BALIĆ I DR.	$V_v = a_0 + a_1 d_{1,3} + a_2 h + a_3 d_{1,3} h + a_4 d_{1,3}^2 + a_5 d_{1,3} h^2$	0,990	0,995	0,240

Legenda:

V_v – volumen krupnog drveta sa korom (m³), zavisna varijabla

$d_{1,3}$ – prsnji promjer sa korom (cm), nezavisna varijabla

h – visina stabla (m), nezavisna varijabla

$a, a_0, a_1, a_2, a_3, a_4, a_5, b, b_0, b_1, b_2, b_3, b_4, c, d, e, f$: parametri funkcija

R² – koeficijent višestruke determinacije

R – koeficijent višestruke korelacije

S_{ey} – standardna greška regresije

Tablica 6: Osnovni statistički pokazatelji regresijskog modela (11) za procjenu volumena stabala smreke

Table 6: Basic statistical indicators of the regression model (11) for estimating the volume of spruce trees

Varijable u regresiji – Variables in regression	Vrijednosti parametara modela - Values of model parameters	Standardna greška – Stan- dard Error of B	t (371)	p-nivo p-level
Slobodni član – Intercept	-3.43452034	0.162187	-21.1763	<0.001
$d_{1,3_transf.}$	0.20231789	0.040199	5.0330	<0.001
$h_transf.$	0.01277572	0.003092	4.1322	<0.001
$d_{1,3_transf.} \cdot h_transf.$	0.00051096	0.000447	2.1422	0.041
$d_{1,3_transf.}^2$	0.00437652	0.002108	2.0757	0.039
$d_{1,3_transf.}^2 \cdot h_transf$	-0.00003774	0.000018	-2.0592	0.040

pouzdano odrediti iz mjerljivih elemenata, kao što su: promjer, visina, koeficijent oblika, dužina krošnje, debljina kore, starost i sl. (Banković i Pantić, 2006). Veći broj argumenata osigurava veću točnost podataka u tablicama, ali i otežava njihovu praktičnu primjenu. Uobičajena je izrada dvoulaznih voluminskih tablica, gdje se kao ulazi koriste promjer stabla izmјeren na „prsnog“ visini ($d_{1,3}$) i visina stabla (h).

U cilju izbora „najboljeg“ modela za procjenu volumena krupnog drveta u ovisnosti o prsnom promjeru i visini stabla testiran je veći broj poznatih dendrometrijskih dvoparametarskih voluminskih funkcija (Kramer i Akça, 2007; Banković i Pantić, 2006; Pranjić i Lukić, 1997) kao i model koji je korišten za konstrukciju postojećih dvoulaznih voluminskih tablica za jelu i smrek u BiH (Stojanović i dr. 1978). Kvaliteta izjednačenja i prikladnost testiranih modela ocjenjivani su na bazi utvrđenih veličina osnovnih statističkih pokazatelja za karakteriziranje jačine korelacijskih veza, i to u ponajprije na osnovi veličine koeficijenta višestruke determinacije (R^2), veličine standardne greške regresije (S_{ey}), veličine F-količnika, značajnosti koeficijenata regresijskog modela te grafičke interpretacije reziduala u odnosu na izabrani model izjednačenja. Rezultati testiranja s obzirom na veličinu osnovnih statističkih parametara, kao i oblici testiranih modela prikazani su u tablici 5, a oblici funkcija izravnjanja preuzeti su iz sljedećih radova: Schumacher i Hall 1933; Meyer, 1941; Näslund 1941, 1947; Stoate 1945; Sputrr 1952; Hansen i Nagel 2012;

Najbolje ocjene parametara s obzirom na postavljene kriterije pokazao je model pod rednim brojem 11. koji je končno i izabran za izražavanje ovisnosti volumena krupnog drveta stabala smreke o prsnom promjeru i visini stabala.

Osim toga, izabrani model sadrži šest parametara, a za dobro izravnjanje je potrebno minimalno četiri parametra (Kružić 1993) pa se isti može koristiti za sva stabla. Karakteristike izabranog modela prikazane su u tablicama (Tablice 6 i 7) i grafički (grafikon 6).

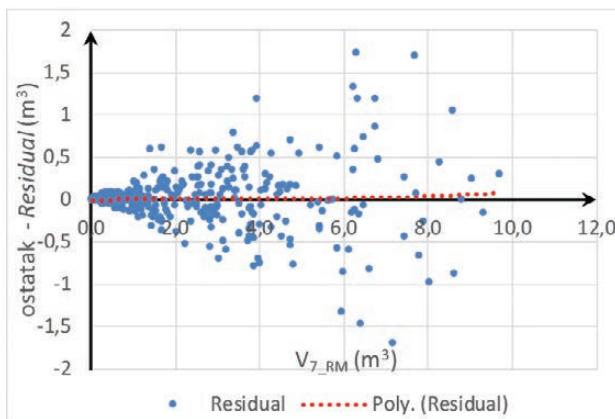
Na temelju grafičkog prikaza distribucije reziduala (grafikon 6) može se navesti da ne postoji značajnije sistematsko rasipanje reziduala, već su oni približno ravnomjerno raspoređeni oko izabranog modela za procjenu zavisne varijable – volumena stabala. Dijagram razdiobe ostataka izravanat je krivuljom parabole II reda, koja bi trebala pratiti tendenciju sistematskog odstupanja i eventualnog grupiranja reziduala u odnosu na veličine procijenjene modelom regresije. Na grafičkom prikazu vidljivo je da se krivulja izjednačenja (koja je prikazana crvenom bojom) u cijelosti poklapa sa X-osi, čime je potvrđena tvrdnja o odsustvu sistematskog rasporeda reziduala u čitavoj domeni funkcije, kao i tvrdnja o nepostojanju (odsustvu) korelacijske veze između veličina reziduala i modelom utvrđenih volumena krupnog drveta stabala smreke (Banković i Pantić 1991; Koprivica i Maunaga 2008).

Grafički prikazi izabranog regresijskog modela predstavljeni su na grafikonima 5 i 6. Na bazi utvrđenih parametara modela konstruirane su grafičke predstave ovisnosti volumena krupnog drveta stabala smreke u ovisnosti o visini u rasponu variranja promjera stabala od 10 – 100 cm (kao volumne linije za $d=10, 20, 30, 40, 50, 60, 70, 80, 90$ i 100 cm) – slika 5. Iz grafikona je vidljiv progresivan krivolinijski (paraboličan) trend povećanja volumena krupnog drveta sa porastom promjera stabala. To je logično ako se ima u vidu oblik utjecaja za promjer stabla, koji je u modelu iska-

Tablica 7. Rezultati analize varijance (ANOVA) za regresijski model (11) za procjenu volumena krupnog drveta stabala smreke

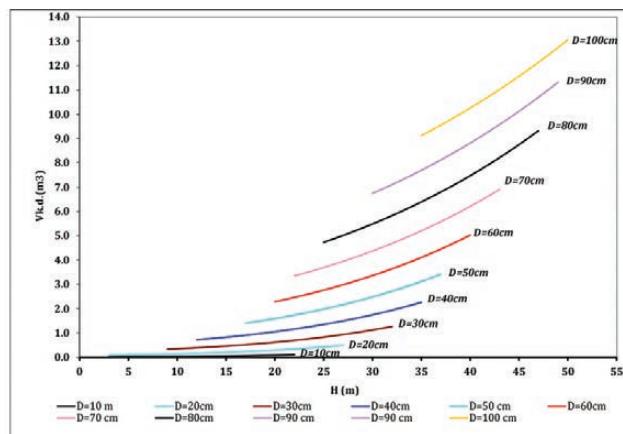
Table 7. Results of the analysis of variance (ANOVA) for the regression model (11) to estimate merchantable wood volume of spruce trees

Izvori variranja Sources of variation	Suma kvadrata Sums of Squares	Stupnjevi slobode Degrees of freedom	Sredina kvadrata Mean Squares	F	p-nivo p -level
Regresija – Regression	711.2229	6.0000	118.5371	7223.33	0.00
Ostatak – Residual	6.0882	371.0000	0.0164		
Ukupno – Total	717.3111	377.0000			



Slika 4. Dijagram razdiobe ostataka oko regresijskog modela za procjenu volumena krupnog drveta stabala smreke

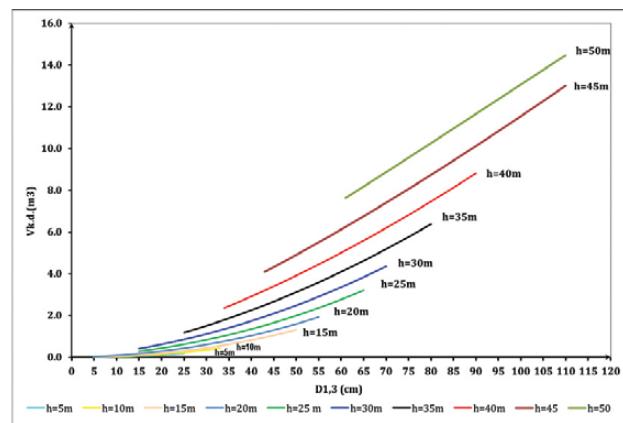
Figure 4. Diagram of dispersion residuals around the regression model to estimate merchantable wood volume of spruce trees



Slika 5. Ovisnost volumena krupnog drveta stabala smreke o visini pri različitim vrijednostima prsnog promjera

Figure 5. Dependence of merchantable wood volume of spruce trees on height and at different breast diameter

zan linearnim i kvadratnim članovima. Osim toga, i u formuli za volumen dubećeg stabla ($V=g_{l,3} h f_{l,3}$) promjer stabala je iskazana kvadratnim članom.



Slika 6. Ovisnost volumena krupnog drveta stabala smreke o prsnom promjeru pri različitim vrijednostima visine stabala

Figure 6. Dependence of merchantable wood volume of spruce trees on breast diameter at different height sizes

Isto tako kreiran je i grafički prikaz ovisnosti volumena krupnog drveta stabala smreke u ovisnosti o promjeru stabala u domenu variranja visina stabala od 5 - 50 m (kao zavojinske linije za $h=5, 10, 15, 20, 25, 30, 35, 40, 45 \text{ i } 50\text{m}$) – slika 6.

Uvrštavanjem veličina izračunatih parametara u izabrani model funkcije (11) dobiveni su sljedeći konačni oblici (transformirani i originalni) regresijskog modela za procjenu volumena krupnog drveta stabala smreke u ovisnosti o prsnom promjeru i visini stabala:

$$\begin{aligned} V_{7_transf} = & ((-3.4345205 + 0.2023179 * ((d_{1,3}^{0.517374}) - 1)) / \\ & (0.517374) + 0.0127757 * ((h^{1.4319967}) - 1) / (1.4319967) + \\ & 0.00051095 * ((d_{1,3}^{0.517374}) - 1) / (0.517374) * ((h^{1.4319967}) - 1) / \\ & (1.4319967) + 0.0043765 * ((d_{1,3}^{0.517374}) - 1) / 0.517374)^2 - \\ & 0.00003774 * ((d_{1,3}^{0.517374}) - 1) / 0.517374)^2 * (h^{1.4319967} - 1) / \\ & 1.4319967 * 0.2612895 + 1)^{3.82717} \end{aligned}$$

Kako je $V_{7_RM} = (0.2612895 * V_{7_transf} + 1)^{3.82717}$ onda konačni oblik regresijskog modela za procjenu volumena stabala smreke na bazi originalnih veličina zavisnih varijabli (prsnog promjera i visine) glasi:

$$\begin{aligned} V_{7_RM} = & 0.26128954 * ((((-3.4345205 + 0.2023179 * ((d_{1,3}^{0.517374}) - \\ & 1) / 0.517374 + 0.0127757 * ((h^{1.4319967}) - 1) / 1.4319967 + \\ & 0.00051095 * ((d_{1,3}^{0.517374}) - 1) / 0.517374 * ((h^{1.4319967}) - 1) / 1.4319967 + \\ & 0.0043765 * ((d_{1,3}^{0.517374}) - 1) / 0.517374)^2 - \\ & 0.00003774 * ((d_{1,3}^{0.517374}) - 1) / 0.517374)^2 * (h^{1.4319967} - 1) / 1.4319967 * 0.2612895 + 1)^{3.82717189} + 1)^{3.82717189} \end{aligned}$$

Na bazi dobivenog regresijskog modela moguće je izračunati volumene krupnog drveta stabala i prikazati ih u formi dvoulaznih tablica volumena stabala smreke.

Testiranje točnosti i upotrebljivosti regresijskog modela – *Testing the accuracy and usability of established regression models*

Volumne tablice sadrže podatke o volumenima stabala određenih dimenzija, pa će pri njihovoju uporabi tablični volumeni za pojedinačna stabala manje ili više odstupati od stvarnih volumena. Koliko će to odstupanje iznositi zavisi od uskladenosti (istovjetnosti) oblika stabala na osnovi kojih su izrađene volumne tablice i stabala kojima se određuje volumen (što su razlike u obliku veće, odstupanja su veća. Ako treba procijeniti (odrediti) volumen samo nekoliko pojedinačnih dubećih stabala po nekim volumnim tablicama, onda treba znati da volumen očitan iz volumnih tablica može odstupati od stvarnog volumena za 10-15% i tada su te tablice neuporabljive. Ove greške od 10-15% se prilikom procjene (određivanja) volumena sastojine smanjuju po poznatom obrascu, tako da su te tablice za sastojinu ipak još uporabljive (Pranjić i Lukić 1997).

Testiranje točnosti tablica, odnosno izabranog regresijskog modela za procjenu volumena proveden je na istoj onoj

bazi podataka koja je poslužila za kreiranje izabranih modela tj. na uzorku od 377 stabala smreke. Uporabljivost tablica testirana je pomoću postotka odstupanja, koji se može izračunati po formuli (Bruce 1920, prema Pranjić i Lukić 1997):

$$p_v = \frac{v_s - v_t}{v_t} \cdot 100 \quad \text{gdje je } V_s - \text{stvarni volumen stabla; } V_t - \text{volumen istog stabla procijenjen pomoću tablica (regresijskih modela).}$$

Na bazi izračunatih postotnih odstupanja za svih 377 stabala, utvrđen je prosječni postotak odstupanja pri čemu je dobivena vrijednost od $\bar{p}_v = 0,44\%$. To zapravo znači da se primjenom navedenog regresijskog modela na uzorak od 377 analiziranih stabala u prosjeku dobivaju za 0,44% manji volumeni u odnosu na stvarne volumene. Prema Pranjić i Lukić (1997), ako je postotak odstupanja veći od $\pm 1\%$, tablice su neuporabljive. To ukazuje da je ovaj regresijski model uporabljiv za primjenu u praktičnom radu.

Kada su tablice izrađene analitičkom metodom, pomoću neke funkcije i kad je poznata standardna devijacija volumena (s_v), upotrebljivost tablica se može ispitati i na sljedeći način: obori se veći broj stabala srednjeg promjera i metodom sekcioniranja im se odrede volumeni (v_s), a zatim se odrede volumeni tih stabala po tablicama (v_t) i izračuna razlika aritmetičkih sredina $\Delta v = \bar{v}_s - \bar{v}_t$. Kako je poznata standardna devijacija volumena (S_v), veličina t se može izračunati po sljedećem obrascu: $t = \frac{\Delta v}{S_v \cdot \sqrt{n}}$. Ako je izra-

čunata vrijednost t manja od tablične $t_{0,05}$, tablice su uporabljive (Banković i dr. 2003). Prema Pranjić i Lukić (1997), ukoliko je broj stabala $n > 30$, usporedba se vrši sa vrijednostima u tablicama normalne distribucije, pa ako je:

$$\Delta v < 1,96 \cdot 0,1 \cdot \frac{\bar{v}_t}{\sqrt{n}} \approx 0,2 \cdot \frac{\bar{v}_t}{\sqrt{n}} \quad \text{u tom slučaju tablice su uporabljive.}$$

Prema Pranjić i Lukić (1997), ukoliko su tablice konstruirane računskim putem, onda se prikladnost istih ispituje

biometriskim metodama testiranja i to pomoću t-testa parova (*t-Test Paired Two Sample for Means*). Da bi se moglo utvrditi u kojoj domeni variranja prsnih promjera su razlike statistički značajne, a u kojoj nisu, provedeno je testiranje po debljinskim klasama po kojima se u BiH prikazuje struktura svih proizvodnih parametara sastojina. Najprije su provedena testiranja značajnosti razlika između stvarnih volumena krupnog drveta ($V_{7_stv.}$) i volumena utvrđenih pomoću regresijskog modela (V_{7_RM}) pri čemu su rezultati testiranja prikazani u tablici 8. Rezultati testiranja ukazuju da u svim debljinskim klasama kao i za volumene svih stabala u uzorku, uvezvi ih zajedno, ne postoje statistički značajne razlike između stvarnih volumena krupnog drveta ($V_{7_stv.}$) i volumena procijenjenih primjenom kreiranog regresijskog modela (V_{7_RM}). Na analogan način, provedeno je testiranje značajnosti razlika volumena procijenjenih primjenom kreiranog regresijskog modela (V_{7_RM}) i volumena očitanih iz dvoulaznih voluminskih tablica – $V_{7_Stoj.}$ (Stojanović i dr. 1978). Rezultati testiranja prikazani su u tablici 9. Rezultati testiranja ukazuju da su u svim debljinskim klasama, kao i za sva stabla u uzorku utvrđene statistički značajne razlike. Za stabla tanja od 30 cm volumeni krupnog drveta procijenjeni na bazi tablica Stojanović i dr. (1978) u prosjeku su veći, dok za stabla deblja od 30 cm u prosjeku su manji u odnosu na volumene procijenjene na bazi kreiranog regresijskog modela. Ako promatramo sva stabla u uzorku (tablica 13), onda volumeni stabala iz uzorka procijenjeni pomoću tablica Stojanović i dr. (1978) su za 189,5 m^3 (ili za 22,3%) viši u odnosu na stvarne volumene tih istih stabala.

Radi usporedbe provedena su testiranja sa rezultatima nekoliko dvoulaznih voluminskih tablica za smreku koje se koriste u Hrvatskoj i Srbiji. Treba uzeti u obzir da je ova usporedba orijentacijskog karaktera, jer daje samo približan uvid u moguće razlike zbog toga jer se ne odnose na isti volumen kao ekvivalent. Naime, tablice za smreku koje se koriste u Hrvatskoj daju volumene stabla s uključenim volumenom panja, dok nam je za tablice u Srbiji ta informacija ostala nepoznata. U Srbiji su Banković i dr. (2003) izra-

Tablica 8. Rezultati testiranja značajnosti razlika pomoću t-testa parova između stvarnih ($V_{7_stv.}$) i procijenjenih volumena krupnog drveta (V_{7_RM}) po debljinskim klasama

Table 8. Results of testing the significance of differences by t-test of pairs between actual and estimated merchantable wood volumes by thickness classes

Statistički parametri t-testa – Statistical parameters of the t-test	$10 \leq d_{1,3} < 20$		$20 \leq d_{1,3} < 30$		$30 \leq d_{1,3} < 50$		$50 \leq d_{1,3} < 80$		$d_{1,3} \geq 80$		Ukupno – Total	
	$V_{7_stv.}$	V_{7_RM}	$V_{7_stv.}$	V_{7_RM}	$V_{7_stv.}$	V_{7_RM}	$V_{7_stv.}$	V_{7_RM}	$V_{7_stv.}$	V_{7_RM}	$V_{7_stv.}$	V_{7_RM}
Sredina – Mean	0.118	0.118	0.448	0.442	1.351	1.353	3.892	3.871	7.969	7.926	2.283	2.273
Varijansa – Variance	0.0044	0.0045	0.0236	0.0228	0.2185	0.1879	1.6709	1.4684	1.5499	0.8908	4.7330	4.5733
Opažanja – Observations	49	49	63	63	111	111	135	135	19	19	377	377
Pearsonova korelacija – Pearson Correlation	0.9658		0.961859		0.9377		0.9356		–		0.9876	
Broj stepena slobode – Df	48		62		110		134		18		376	
Izračunata vrijednost t – t Stat	0.0960		1.0852		-0.1432		0.5390		0.2230		0.5741	
Nivo značajnosti P($T \leq t$) two-tail	0.9239		0.2820		0.8864		0.5908		0.8261		0.5663	
Kritična vrijednost t-testa – t Critical two-tail	2.0106		1.9990		1.9818		1.9778		2.1009		1.9663	

Tablica 9. Rezultati testiranja značajnosti razlika pomoću t-testa parova između volumena iz dvolaznih volumenskih tablica (Stojanović i dr. 1978) i volumena izračunatih pomoću izrađenog regresijskog modela po debljinskim klasama

Table 9. - Results of testing the significance of differences by t-test of pairs between volumes calculated on the basis of the chosen regression model and volumes from two-way volume tables (Stojanovic, i dr. 1978) by thickness classes

Statistički parametri t-testa – Statistical parameters of the t-test	$10 \leq d_{1,3} < 20$		$20 \leq d_{1,3} < 30$		$30 \leq d_{1,3} < 50$		$50 \leq d_{1,3} < 80$		$d_{1,3} \geq 80$		Ukupno – Total	
	V_{7_RM}	$V_{7_Stoj.}$	V_{7_RM}	$V_{7_Stoj.}$	V_{7_RM}	$V_{7_Stoj.}$	V_{7_RM}	$V_{7_Stoj.}$	V_{7_RM}	$V_{7_Stoj.}$	V_{7_RM}	$V_{7_Stoj.}$
Sredina – Mean	0.118	0.1215	0.442	0.451	1.353	1.318	3.871	3.670	7.926	7.481	2.274	2.178
Varijansa – Variance	0.0045	0.0050	0.0228	0.0232	0.1879	0.1635	1.4684	1.6215	0.8908	0.7419	4.5733	4.1759
Opažanja – Observations	49	49	63	63	111	111	135	135	19	19	377	377
Pearsonova korelacija – Pearson Correlation	0.9970		0.9851		0.9977		0.9731		0.7576		0.9937	
Broj stepena slobode – Df	48		62		110		134		18		376	
Izračunata vrijednost t – t Stat	-3.6446		-2.8346		9.0658		7.1524		3.0635		7.3533	
Nivo značajnosti P($T \leq t$) two-tail	0.0007		0.0062		<0.001		<0.001		0.0067		<0.001	
Kritična vrijednost t-testa – t Critical two-tail	2.0106		1.9990		1.9818		1.9778		2.1009		1.9663	

Tablica 10. Rezultati testiranja značajnosti razlika pomoću t-testa parova između volumena izračunatih pomoću regresijskog modela za planinski pojas Kopaonika (Banković i dr. 2003) i volumena izračunatih pomoću izrađenog regresijskog modela po debljinskim klasama

Table 10. - Results of testing the significance of differences by t-test of pairs between the volumes calculated on the basis of regression model for the Kopaonik mountain Beilt (Banković i dr. 2003) and the volumes calculated using the created regression model by thickness classes

Statistički parametri t-testa – Statistical parameters of the t-test	$10 \leq d_{1,3} < 20$		$20 \leq d_{1,3} < 30$		$30 \leq d_{1,3} < 50$		$50 \leq d_{1,3} < 80$		$d_{1,3} \geq 80$		Ukupno – Total	
	V_{7_RM}	$V_{7_Bank. Pl.}$	V_{7_RM}	$V_{7_Bank. Pl.}$	V_{7_RM}	$V_{7_Bank. Pl.}$						
Sredina – Mean	0.118	0.156	0.442	0.526	1.353	1.483	3.871	4.113	7.926	8.585	2.273	2.450
Varijansa – Variance	0.004	0.006	0.0228	0.0247	0.188	0.204	1.468	1.622	0.891	1.142	4.5733	5.1752
Opažanja – Observations	49	49	63	63	111	111	135.000	135.000	19	19	377	377
Pearsonova korelacija – Pearson Correlation	0.997		0.997		0.997		0.999		0.994		0.9996	
Broj stepena slobode – Df	48		62		110		134		18		376	
Izračunata vrijednost t – t Stat	-20.268		-46.799		-35.290		-31.210		-17.177		-22.788	
Nivo značajnosti P($T \leq t$) two-tail	<0.001		<0.001		<0.001		<0.001		<0.001		<0.001	
Kritična vrijednost t-testa – t Critical two-tail	2.011		1.999		1.982		1.978		2.101		1.9663	

Tablica 11. Rezultati testiranja značajnosti razlika pomoću t-testa parova između volumena izračunatih pomoću regresijskog modela za subalpski pojas Kopaonika (Banković i dr. 2003) i volumena izračunatih pomoću izrađenog regresijskog modela po debljinskim klasama

Table 11. Results of testing the significance of differences using the t-test of pairs between the volumes calculated on the basis of regression model for the Kopaonik Sub-Alpine Belt (Banković i dr. 2003) and the volumes calculated using the created regression model by thickness classes

Statistički parametri t-testa – Statistical parameters of the t-test	$10 \leq d_{1,3} < 20$		$20 \leq d_{1,3} < 30$		$30 \leq d_{1,3} < 50$		$50 \leq d_{1,3} < 80$		$d_{1,3} \geq 80$		Ukupno – Total	
	V_{7_RM}	$V_{7_Bank. SA}$	V_{7_RM}	$V_{7_Bank. SA}$	V_{7_RM}	$V_{7_Bank. SA}$						
Sredina – Mean	0.118	0.131	0.442	0.449	1.353	1.309	3.871	3.761	7.926	8.033	2.273	2.229
Varijansa – Variance	0.004	0.004	0.023	0.018	0.188	0.171	1.4684	1.4296	0.891	1.118	4.5733	4.5156
Opažanja – Observations	49	49	63	63	111	111	135	135	19	19	377	377
Pearsonova korelacija – Pearson Correlation	0.995		0.994		0.994		0.997		0.983		0.9989	
Broj stepena slobode – Df	48		62		110		134		18		376	
Izračunata vrijednost t – t Stat	-13.646		-2.553		9.397		13.432		-2.166		8.6559	
Nivo značajnosti – P($T \leq t$) two-tail	<0.001		0.013		<0.001		<0.001		0.044		<0.001	
Kritična vrijednost t-testa – t Critical two-tail	2.011		1.999		1.982		1.978		2.101		1.9663	

dili zapremske tablice za smreku za područje nacionalnog parka Kopaonik i to odvojeno za planinski pojas ($V_{7_Bank. Pl.}$) i za subalpski pojas ($V_{7_Bank. SA}$). Za kreiranje regresijskih modela za procjenu volumena stabala smreke za prvi model korišteno je 201 stabala, a za drugi 393 stabala. Za izravnanje volumena stabala smreke u ovisnosti o prsnom promjeru i visini korištena je Schumacher-Hallova funkcija (Schumacher i Hall 1933). Rezultati testiranja značajnosti

razlika između volumena izračunatih pomoću ovih regresijskih modela (Banković i dr. 2003) i volumena izračunatih pomoću izrađenog regresijskog modela po debljinskim klasama prikazani su u tablicama 10 i 11. Rezultati testiranja pokazuju da se za oba modela u svim debljinskim klasama, kao i za sva stabla u uzorku utvrđene statistički značajne razlike u odnosu na volumene procijenjene na bazi izrađenog modela. Ipak, model koji je izrađen za stabla

Tablica 12. Rezultati testiranja značajnosti razlika pomoću t-testa parova između volumena iz dvolaznih volumenskih tablica (Špiranec, 1977) i volumena izračunatih pomoću izrađenog regresijskog modela po debljinskim klasama

Table 12. Results of testing the significance of differences by t-test of pairs between volumes calculated on the basis of the chosen regression model and volumes from two-tier volume tables (Špiranec, 1977) by thickness classes

Statistički parametri t-testa – Statistical parameters of the t-test	10 ≤ d _{1,3} < 20		20 ≤ d _{1,3} < 30		30 ≤ d _{1,3} < 50		50 ≤ d _{1,3} < 80		d _{1,3} ≥ 80		Ukupno – Total	
	V _{7_RM}	V _{7_Spiranec}	V _{7_RM}	V _{7_Spiranec}	V _{7_RM}	V _{7_Spiranec}						
Sredina – Mean	0.118	0.118	0.448	0.443	1.353	1.371	3.871	4.159	7.926	9.229	2.273	2.447
Varijansa – Variance	0.0044	0.0043	0.0236	0.0210	0.1879	0.2063	1.4684	1.9864	0.8908	1.5479	4.5733	5.9443
Opažanja – Observations	49	49	63	63	111	111	135	135	19	19	377	377
Pearsonova korelacija – Pearson Correlation	0.9713		0.9606		0.9976		0.9987		0.9953		0.9984	
Broj stepena slobode – Df	48		62		110		134		18		376	
Izračunata vrijednost t – t Stat	0.0163		0.9096		-4.8927		-16.038		-17.856		-10.369	
Nivo značajnosti – P(T<=t) two-tail	0.9871		0.3666		<0.001		<0.001		<0.001		<0.001	
Kritična vrijednost t-testa – t Critical two-tail	2.0106		1.9990		1.9818		1.9778		2.1009		1.9663	

Tablica 13. Razlike u volumenima krupnog drveta iz uzorka procijenjeni na bazi različitih modela

Table 13. Differences in the merchantable wood volumes from the sample estimated on the basis of different models

Debljinski stupanj DBH Class	Razlike između stvarnih i modelom procijenjenih volumena Differences between actual and model estimated volumes – (m ³)				
	V _{7_stvarna} – V _{7_Balić et al.}	V _{7_stvarna} – V _{7_Stojanović et al.}	V _{7_stvarna} – V _{7_Banković et al._SubA}	V _{7_stvarna} – V _{7_Banković et al._Plan.}	V _{7_stvarna} – V _{7_Spiranec}
12.5	0.01	-0.68	-0.22	-0.59	0.03
17.5	0.00	-1.70	-0.26	-1.10	0.13
22.5	0.25	-3.37	-0.25	-2.13	0.18
27.5	0.11	-4.48	0.25	-2.64	0.28
32.5	-0.24	-6.26	1.05	-3.27	0.23
37.5	-0.24	-8.76	0.91	-4.23	-0.47
42.5	0.32	-8.02	1.66	-3.20	-0.29
47.5	-0.07	-9.67	1.18	-3.75	-1.39
52.5	1.28	-14.25	4.89	-3.54	-1.33
57.5	0.91	-16.40	3.95	-4.57	-3.30
62.5	-1.12	-21.77	2.12	-6.84	-7.17
67.5	2.34	-21.48	4.78	-4.42	-6.17
72.5	-2.24	-17.31	0.10	-6.00	-8.98
77.5	1.68	-17.96	2.23	-3.97	-8.22
82.5	5.13	-5.61	5.60	2.22	-0.85
87.5	-4.67	-23.62	-5.55	-10.57	-16.11
92.5	-0.16	-2.59	-0.19	-0.91	-1.86
97.5	0.25	-5.55	-0.73	-1.74	-3.43
Ukupna razlika Total difference (m ³)	3.23	-189.48	21.51	-61.27	-58.74
%	0.42	-22.27	2.53	-7.20	-6.90

smreke iz subalpskog pojasa ($V_{7_Bank.SA}$) pokazuje nešto manja odstupanja s našim modelom u odnosu na model koji je izrađen za stabla smreke iz planinskog pojasa ($V_{7_Bank.Pl}$) koji u svim debljinskim klasama daje veće volumene u odnosu na izrađeni regresijski model. U odnosu na stvarne volumene, modelom koji je izrađen za stabla smreke za subalpski pojase dobivaju se nešto manji volumeni za 21,5 m³ (ili za 2,5%) dok se modelom koji je izrađen za stabla

smreke za planinski pojase dobivaju veći volumeni za 61,3 m³ (ili za 7,2%). To je i logično ako se ima u vidu forma stabala smreke iz subalpskog pojasa Kopaonika, koja su pri jednakim veličinama promjera u prosjeku niža i malodrvnija u odnosu na stabla smreke istih dimenzija iz planinskog pojasa Kopaonika.

U susjednoj Hrvatskoj Špiranec je izradio tablice drvnih masa za smreku i to na bazi 750 modelnih stabala, pri čemu je za kreiranje regresijskog modela za procjenu ukupnog volumena stabala smreke u ovisnosti o prsnim promjerima i visinama također koristio Schumacher-Hallovu funkciju (Špiranec 1976). Tablice za deblovine su dobivene množenjem vrijednosti ukupnog volumena s izrađenim tablicama postotka deblovine u ukupnom volumenu stabla (Špiranec 1976, str. 5 i str. 16). Osim toga, u volumenu deblovine uračunat je i volumen panja. Rezultati testiranja značajnosti razlike između volumena izračunatih pomoću tablica Špiraneca (Špiranec 1976) i volumena izračunatih primjenom kreiranog regresijskog modela po debljinskim klasama prikazani su u tablici 12. Rezultati testiranja pokazuju da za stabla tanja od 30 cm ne postoje značajne razlike u volumenima stabala, dok za stabla deblja od 30 cm volumeni procijenjeni na bazi regresijskog modela (Špiranec 1976) su u prosjeku veći u odnosu na volumene procijenjene primjenom izrađenog regresijskog modela. U odnosu na stvarne zapremine, navedenim modelom se za uzorak od 377 stabala dobivaju nešto veći volumeni, i to za $58,7 \text{ m}^3$ (ili za 6,9%)

ZAKLJUČCI CONCLUSIONS

Na području Kantona 10 (Livanjski kanton) Federacije Bosne i Hercegovine, provedena su istraživanja oblika stabala smreke na uzorku od 377 modelnih stabala na kojima su u oborenom stanju metodom sekcioniranja utvrđeni volumeni krupnog drveta. Na bazi provedenih istraživanja izrađen je model za procjenu volumena krupnog drveta stabala smreke u ovisnosti o prsnom promjeru i visini stabala sljedećeg oblika: $V_7 = a_0 + a_1 d_{1,3} + a_2 h + a_3 d_{1,3} h + a_4 d_{1,3}^2 + a_5 d_{1,3}^2 h$ uz utvrđeni koeficijent determinacije: $R^2 = 0,99$ i veličinu standardne greške regresije $S_{ey} = 0,24 \text{ m}^3$. Testirajući značajnost razlike između stvarnih volumena stabala iz uzorka i volumena tih istih stabala utvrđenih primjenom odabranog regresijskog modela nisu utvrđene statistički značajne razlike. Prosječni postotak odstupanja iznosi je - 0,44%. To znači da se na uzorku od 377 stabala smreke u prosjeku dobivaju za 0,44% niži volumeni u odnosu na stvarne volumene, što ukazuje da je ovaj regresijski model upotrebljiv za primjenu u praktičnom radu, jer je prosječni postotak odstupanja manji od 1%. Statistički značajne razlike utvrđene su između volumena stabala utvrđenih primjenom odabranog regresijskog modela i volumnih tablica drugih autora (Stojanović i dr. 1978; Banković i dr. 2003; Špiranec 1976). Ta odstupanja variraju u rasponu od 2,53% pa sve do 22,7%. Najveća odstupanja su utvrđena upravo kod modela koji se primjenjuje u BiH (Stojanović i dr. 1978) i iznose 22,7% dok su najmanja odstupanja utvrđena za volumene procijenjene pomoću modela koji je kreiran za stabla smreke iz subalpijskog pojasa planine Kopaonik (Banković i dr. 2003) i iznose 2,53 %. Imajući u vidu značaj i aktualnost ovih

istraživanja za šumarsku praksu, potrebno je nastaviti sa sličnim istraživanjima za druge gospodarski značajne šumske vrste drveća, kako za ovo, tako i za područje ostalih kantona u Federaciji Bosne i Hercegovine.

LITERATURA

REFERENCES

- Banković, S., Medarević, M., Pantić, D., Filipović, M., 2003: Zapreminske tablice za smrču na području nacionalnog parka Kopaonik. Šumarstvo 2-3, UŠIT, Beograd: 51-60.
- Banković, S., Pantić, D., 2006: Dendrometrija. Šumarski fakultet Univerziteta u Beogradu. Str.1-256.
- Box, G, Cox, D. R., 1964: An Analysis of Transformations. *J Roy Stat Soc B Met* 26 (2): 211-252.
- Drinić, P., Matić, V., Pavlić, J., Prolić, N., Stojanović, O., Vukmirović, V., Koprivica, M. 1990: Tablice taksacionih elemenata visokih i izdanačkih šuma u Bosni i Hercegovini. Posebno izdanje. Šumarski fakultet. 327 S.
- Koprivica, M., Maunaga Z., 2008: Oblik i zapremina vretena stabla smrče u jednodobnim sastojinama na području Bosne. Šumarski fakultet Univerziteta u Banja Luci. Str.1-81.
- Kramer, H., Akça, A., 2008: Leitfaden zur Waldmesslehre. J.D.Sauerländer's Verlag. 5. erweiterte Auflage. Frankfurt am Main. Str.1-210.
- Kružić, T., 1993: Izbor regresijskog modela za izjednačenje drvno-gromadnih tablica. Glas. sum. pokuse: 29:149-198.
- Meyer, H. A., 1941: A Correction for a Systematic Error Occuring in the Aplication of the Logarithmic Volume Equation. The Pennsylvania State Forest School, Research Paper 7.
- Hansen, J., Nagel, J., 2012: Waldwachstumskundliche Softwaresysteme auf Basis von TreeGrOSS - Anwendung und theoretische Grundlagen. Universitätverlag Göttingen, 224. p.
- Näslund, M., 1941: Funktionen und Tabellen zur Kubierung stehender Baume, Kiefer, Fichte und Birke in Nordschweden. Medd. Skogsforstn lost., Stockh., 32.
- Näslund, M., 1947: Functions and tables for computing cubic volume of standing trees, pine, spruce and birch in southern Sweden and in whole of Sweden. Medd. Skogsforstn lost., Stockh.:1-36.
- Pranjic, A., Lukic, N. 1997: Izmjera šuma. Šumarski Fakultet Sveučilišta u Zagrebu. Str.1-410.
- Schumacher, F. X., F. D. S. Hall, 1933: Logarithmic expression of timber-tree volume., Journ. of Agr. Res. 47/9:719-734, Washington.
- Spurr, S. H., 1952: Forest Inventory. The Ronald Press Company, New York, 476 p.
- StatSoft, Inc., 2007: STATISTICA (data analysis software system), version 8.0. www.statsoft.com.
- Stoate, T. N. 1945: The use of a volume equation in pine stands. Australian Forestry 9: 48-52.
- Stojanović, O., Pavlić, J., Prolić, N., 1976: Tablice zapremina stabala krupnog drveta za smrču: 171-191 u: Drinić, P., Matić, V., Pavlić, J., Prolić, N., Stojanović, O., Vukmirović, V., Koprivica, M. 1990: Tablice taksacionih elemenata visokih i izdanačkih šuma u Bosni i Hercegovini. Posebno izdanje. Šumarski fakultet Sarajevo. 327 S.
- Špiranec, M., 1976: Tablice drvnih masa jele i smreke. Radovi. Br. 29. Šumarski institut Jastrebarsko. Zajednica šumarstva, prerađe drva i prometa drvnim proizvodima i papirom. Zagreb.

SUMMARY

For assessment of growing stock in B&H forestry praxis as scientific baseline we are using volume tables and tariffs (Drinić dr. 1990). Having in mind the fact that these are constructed based on volume coefficients of the trees taken from German tree volume tables, which originate from single-age assortments, it is justified to suspect that by applying these tables one will get certain differences in quantity of large wood mass related to the actual status of those volumes. It is known that trees of the same tree species coming from single-age assortments are more full-bodied because they have larger volume coefficients compared to the trees of the same species from variable aged and selection forest assortments. That is why the objective of this research is to find "the best" regression model for levelling of volume of large wood of spruce, as dependent variable depending on diameter at breast height and tree height, as independent variables. To achieve this objective we have selected 377 model trees of spruce that were measured in felled condition on wider area of state owned variable aged assortments in Canton 10 (Livno Canton). To determine volume of large wood of trees we applied section method with sections of uneven absolute lengths (most often from 1 – 2 m). For levelling of volumes of large wood depending on diameter at breast height and tree height we applied method of multi-regression analysis. Quality of levelling and appropriateness of tested models was evaluated on the basis of determined values of basic statistical indicators for characterisation of the strength of correlation connections. The best values of the parameters showed model: $V_7 = a_0 + a_1 d_{1,3} + a_2 h + a_3 d_{1,3}h + a_4 d_{1,3}^2 + a_5 d_{1,3}^2h$ with determined determination coefficient: $R^2 = 0,99$ and size of standard regression error: $S_{ey} = 0,245 \text{ m}^3$. By testing significance of differences between actual/real tree volumes from the sample and volume of those trees determined by application of selected regression model by using t -test of pairs, no statistically significant differences were recorded. Average percentage of deviation was -0.44%. That means that in average we get 0.44% lower volumes comparing to the actual volumes in the sample of 377 spruce trees which shows that this regression model is usable for application in practice, because that average percentage is less than 1%. Statistically significant differences were recorded between volumes of trees of selected regression model and volume tables and models of other authors (Stojanović i dr. 1978; Banković i dr. 2003; Špiranec, 1976.). Those deviations vary in the range from 2.53% up to 22.7%. The largest deviations were determined exactly in model that is used in B&H (Stojanović i dr. 1978) and are in amount of 22.7% while the lower deviations were determined for volumes estimated by using model created for spruce trees from Sub-Alpine belt for area of Kopaonik (Banković i dr. 2003) and those amount to 2.53%.

KEY WORDS: spruce, merchantable wood volume, regression model, nonlinear regression, two-entry volume tables.